



Optimasi Support Vector Machine Particle Swarm Optimization Untuk Prediksi Konsumsi Energi Listrik

Mohamad Ilyas Abas*, Irawan Ibrahim

Universitas Muhammadiyah Gorontalo, Indonesia

*Penulis korespondensi, email: ilyasabas@umgo.ac.id

Abstract

This study aims to analyze the consumption of electrical energy in Gorontalo and make predictions on the use of electrical energy. Electricity consumption and load in Gorontalo is the subject of this research. The method used in making predictions is SVM and PSO Optimization. This algorithm was chosen because it has a high accuracy value with a low error rate. The results of this study indicate that SVM-PSO is able to make predictions with time-series data with small errors. In addition, the results of this study can be used to prepare long-term electricity supply and can socialize good use of electricity to the public. Alternative energy can also be a solution for the government to increase the supply of electrical energy so that people's needs for electricity can be met.

Keywords: *electricity consumption; SVM-PSO; time-series prediction*

Abstrak

Penelitian ini bertujuan untuk menganalisis konsumsi energi listrik di Gorontalo dan melakukan prediksi terhadap penggunaan energi listrik. Konsumsi dan beban listrik di Gorontalo menjadi pokok bahasan dalam penelitian ini. Metode yang digunakan dalam melakukan prediksi yakni SVM dan Optimasi PSO. Algoritma ini dipilih karena memiliki nilai akurasi yang tinggi dengan tingkat *error* yang rendah. Hasil dari penelitian ini menunjukkan bahwa SVM-PSO mampu melakukan prediksi dengan data *time-series* dengan *error* yang kecil. Selain itu, hasil dari penelitian ini dapat digunakan untuk mempersiapkan pasokan listrik jangka panjang serta dapat mensosialisasikan penggunaan listrik yang baik kepada masyarakat. Energi alternatif juga dapat menjadi solusi bagi pemerintah guna menambah pasokan energi listrik sehingga kebutuhan masyarakat akan listrik dapat terpenuhi.

Kata kunci: *konsumsi energi listrik; SVM-PSO; prediksi time-series*

PENDAHULUAN

Energi adalah representasi dari pelayanan pemerintah untuk menyediakannya. Energi khususnya listrik merupakan kebutuhan utama masyarakat dalam rangka melakukan aktivitas sehari-hari. Mulai untuk rumah, kantor, rumah sakit, gedung pemerintahan, usaha dan lain sebagainya. Gorontalo selain dikenal sebagai provinsi jagung juga memiliki permasalahan pasokan listrik. Untuk saat ini kelistrikan provinsi Gorontalo masih suplai ke tetangga tepatnya Sulut-Amurang sebesar 375 MW sedangkan beban puncak mencapai 325 MW (Gorontalo, 2018). Jika mengalami kerusakan terhadap suplai listrik tersebut semua kabupaten/kota di Gorontalo mengalami pemadaman total. Hal ini dapat menjadi perhatian lebih bagi pemerintah melalui Perusahaan Listrik Negara (PLN) agar dapat meningkatkan dan menambah pasokan energi listrik di Gorontalo.

Dilihat dari latar belakang di atas tentunya masalah listrik ini perlu mendapat perhatian karena menyebabkan terjadinya pemadaman bergilir di Gorontalo. Hal itu dilakukan PLN guna menghemat energi listrik jangka panjang. Tidak semua masyarakat dapat memahami hal tersebut. Hampir semua usaha, UMKM, gedung pemerintah, toko dan lain sebagainya membutuhkan listrik 1x24 jam. Apabila dilakukan pemadaman maka usaha tersebut akan mengalami kerugian bahkan menghentikan usahanya. Tentu ditinjau dari segi ekonomi hal ini kurang baik, dikarenakan pemadaman dilakukan rata-rata lebih dari 3 jam atau 8 jam. Bahkan pada beberapa hari rutin adanya pemadaman dengan alasan teknis maupun non-teknis. Pemerintah melalui dinas terkait perlu mempersiapkan energi terbarukan sebagai alternatif bahkan sebagai energi utama jangka panjang untuk mengatasi masalah kelistrikan (Juaidi dkk, 2016).

Hal ini dijadikan alasan bagi peneliti agar menganalisis konsumsi energi listrik dengan melalui data yang ada. Peneliti juga akan melakukan pengumpulan data di Dinas Penanaman Modal, ESDM dan Transmigrasi Provinsi Gorontalo untuk memperoleh data secara *time-series* konsumsi listrik di Gorontalo. Data yang didapatkan akan di pola berdasarkan *period* dan diprediksi menggunakan algoritma *SVM-PSO* guna mencari *error* terkecil dalam prediksi (Karazmodeh dkk, 2013).

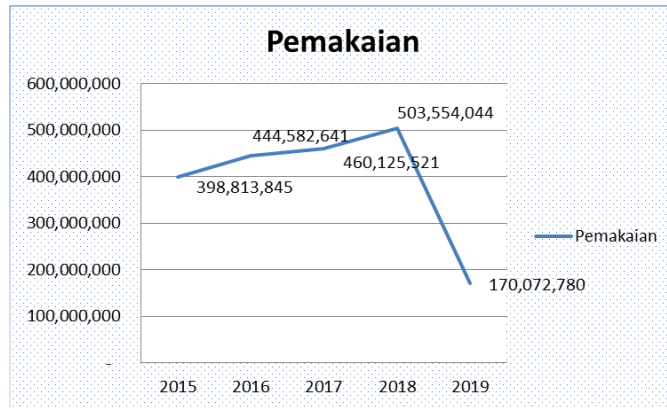
Melalui penelitian ini diharapkan dapat memperoleh informasi tentang konsumsi listrik masyarakat Gorontalo, data konsumsi dan beban listrik wilayah Gorontalo dan juga solusi pemerintah dalam upaya menambah pasokan listrik.

METODE

Metode yang digunakan yakni *SVM*, *SVM* biasanya hanya dilakukan untuk klasifikasi dan *clustering* tetapi pada kasus ini algoritma *SVM* digunakan untuk melakukan prediksi.

Pengumpulan dan Analisis Data

Pengumpulan data dilakukan di PLN Gorontalo dengan mengambil data *time-series* penggunaan konsumsi listrik setiap bulan. Data yang berhasil di ambil mulai dari tahun 2015 sampai 2019 (Gambar 1).




Gambar 1. Data listrik PLN Gorontalo dari Januari 2015 sampai April 2019
 Sumber: PLN Cabang Gorontalo

Data yang diambil mulai bulan Januari 2015 sampai April 2019. Dari data tersebut kemudian akan dilakukan *preprocessing* data dengan membuat pola data dari *univariate* ke *multivariate*.

Preprocessing

Tahapan selanjutnya yakni mengubah data yang diolah dari data *univariate* ke data *multivariate* yaitu dengan mengubah data mulai x_t , x_{t-1} , sampai dengan x_{t-10} . Hal ini bertujuan untuk mencari pola terbaik untuk melakukan prediksi. Pola terbaik akan ditentukan dengan melihat parameter *Root Mean Squared Error* (RMSE) paling terkecil dari hasil analisis n . Tujuan *time-series multivariate* yaitu memodelkan peubah data yang berkorelasi dan tercatat dari waktu ke waktu. Peubah tersebut dinotasikan dalam skema (Gambar 2) dan tabel pola data *time-series*.



Gambar 2. Skema data *univariate* menjadi *multivariate*

Pola data yang digunakan untuk mengubah data *univariate* menjadi *multivariate*, hal ini dapat dilihat pada Tabel 1.

Tabel 1. Pola data *time-series* (*univariate* ke *multivariate*) (Purwanto dkk., 2011)

Pattern	Input lag	Output/ Target
1	$x_1, x_2, x_3, x_4, \dots, x_p$	x_{p+1}
2	$x_2, x_3, x_4, x_5, \dots, x_{p+1}$	x_{p+2}
3	$x_3, x_4, x_5, x_6, \dots, x_{p+2}$	x_{p+3}
...
$m-p$	$x_{m-p}, x_{m-p+1}, x_{m-p+2}, \dots, x_{m-1}$	x_m

Tabel 1 merupakan pola yang digunakan untuk mengubah data *univariate* ke *multivariate* dimana:

$m-p$: nilai pattern

$xm-p$: input lag

xm : Output/Target

model : $xm = xm-p, xm-p+1, xm-p+2, \dots, xm-1$ (1)

SVM-PSO

Metode yang akan digunakan pada penelitian ini adalah *SVM* dengan optimasi *PSO* untuk melakukan analisis prediksi konsumsi listrik. Untuk mendapatkan nilai *RMSE* terkecil dan akurasi yang tinggi optimasi dilakukan dengan menambah *PSO* (Zhang dkk, 2019). Dengan data *time-series* konsumsi listrik masyarakat di Gorontalo. kemudian data tersebut diubah dari *univariate* ke *multivariate* model. Data tersebut diubah menjadi *multivariate* model dari ($x1, x2, \dots, xm$) pola terbaik akan membuat proses analisis menjadi lebih baik. Dari proses perubahan model data ke *multivariate* tersebut barulah kemudian data akan diolah menggunakan metode *SVM-PSO* untuk mendapatkan nilai *RMSE* yang terkecil dan akurasi yang baik. Optimasi *PSO* dapat menurunkan nilai *error* apabila hanya menggunakan *SVM*. Diharapkan dengan penambahan parameter *PSO* akan mendapatkan hasil terbaik yang didapat dari proses analisis yang hanya menggunakan *SVM*. Sehingga, dapat meningkatkan *performance* untuk memperbaiki nilai *RMSE*. Nilai *RMSE* yang baik akan membuat penerapan kombinasi algoritma ini akan mencapai keakuratan dalam melakukan prediksi. Selain menggunakan *SVM-PSO* peneliti juga melakukan uji-coba terhadap *NNGA* karena untuk membandingkan seberapa baik *NNGA* dalam melakukan prediksi (Abas & Lasarudin, 2019).

Prediksi

Tahapan terakhir dari penelitian ini yakni prediksi, prediksi dilakukan untuk data tahun mendatang dengan melakukan uji-coba terlebih dahulu terhadap data yang sudah ada. Penelitian ini juga menghasilkan analisis tentang penggunaan energi listrik di Gorontalo. Tetapi sebelumnya menguji algoritma *SVM-PSO* dengan melakukan prediksi terhadap data yang sudah ada untuk mengetahui seberapa efektif algoritma *SVM-PSO* dalam melakukan prediksi.

HASIL DAN DISKUSI

Dari data yang didapatkan memang pada dasarnya masih kurang karena setelah melakukan pengumpulan data di PLN Gorontalo ternyata pihak PLN Gorontalo hanya memiliki data 5 tahun sebelumnya. Data yang diperoleh sebesar 52 *record data* yang terdiri dari data Januari 2015 sampai April 2019. Pemakaian terendah sebesar 29,746,956 kwh dan pemakaian terbesar 44,715059 kwh dari semua *record data*. Untuk total pemakaian berangsur meningkat mulai tahun 2015 sampai 2019. Dari hasil pengolahan data menggunakan *SVM-PSO* menunjukkan hasil yang cukup baik untuk hal prediksi. Seperti telah dijelaskan sebelumnya memang *SVM-PSO* masih memiliki *error* yang cukup besar dibandingkan dengan *NN-GA* tetapi hasil pengolahan data menunjukkan bahwa *SVM-PSO* juga dapat digunakan untuk memprediksi data listrik secara *time-series*. Hal itu dapat dilihat dari Tabel 2.

Kernel Model

Total number of Support Vectors: 50

Bias (offset): 38119069.340

$w[xt-2] = 13.066$

$w[xt-1] = 13.842$

Tabel 2. Prediksi terhadap data xt

No	xt-2	xt-1	xt	<i>prediction</i> [xt]
1	43687056	41762127	41084924	37936234
2	37772321	36975930	34617729	37936200
3	36772328	36600388	38969985	37936195
4	38075717	37322944	36798297	37936202
5	35164149	36031215	31810124	37936189
6	40255558	40801483	37118014	38075741
7	34602544	33418411	33556257	38075695
8	32275555	33385954	34602544	38075688
9	34017660	32275555	33385954	38075689
10	31810124	34017660	32275555	38075688
11	38686525	40951155	44715059	37772334
12	38046485	44052735	43562424	37772343
13	36975930	34617729	38046485	37772307
14	38969985	37772321	36975930	37772324
15	33385954	34602544	33418411	37772296
16	34617729	38046485	44052735	38046489
17	37130260	37936198	37036963	38046498
18	39266640	37282779	37033336	38046502
19	31631562	39266640	37282779	38046484
20	33173458	29746956	31631562	38046454
21	43993087	38838432	42526202	37322967
22	40163668	43687056	41762127	37322973
23	44052735	43562424	43262063	37322984
24	35872096	33690074	43777760	37322924
25	36031215	31810124	34017660	37322918
26	40951155	44715059	43993087	37322976
27	42333772	41917547	40163668	37322971
28	42090048	42333772	41917547	37322972
29	43262063	42090048	42333772	37322974
30	37322944	36798297	35872096	37322940
31	41762127	41084924	38686525	37772343
32	43777760	40255558	40801483	37772347
33	37936198	37036963	37137337	37772319
34	37033336	37130260	37936198	37772316
35	33556257	33173458	29746956	37772293
36	44715059	43993087	38838432	37772371
37	37118014	38417540	36772328	37772321
38	37036963	37137337	38075717	37772316
39	37282779	37033336	37130260	37772316
40	29746956	31631562	39266640	37772267
41	41084924	38686525	40951155	37936215
42	43562424	43262063	42090048	37936238
43	36600388	38969985	37772321	37936203
44	38417540	36772328	36600388	37936201

No	xt-2	xt-1	xt	prediction [xt]
45	36798297	35872096	33690074	37936193
46	41917547	40163668	43687056	37772342
47	40801483	37118014	38417540	37772328
48	33690074	43777760	40255558	37772328
49	37137337	38075717	37322944	37772320
50	33418411	33556257	33173458	37772293

Tabel 2 menjelaskan bahwa terjadi selisih yang cukup kecil antara data faktual (xt) dari hasil prediksi yang dilakukan (*prediction* [xt]). Tabel 3 menunjukkan selisih faktual dan hasil prediksi *SVM-PSO*.

Tabel 3. Selisih data xt : *prediction* (xt)

No	xt-2	xt-1	xt	prediction (xt)	selisih
1	43687056	41762127	41084924	7936234	3,148,690
2	37772321	36975930	34617729	37936200	(3,318,471)
3	36772328	36600388	38969985	37936195	1,033,790
4	38075717	37322944	36798297	37936202	(1,137,905)
5	35164149	36031215	31810124	37936189	(6,126,065)
6	40255558	40801483	37118014	38075741	(957,727)
7	34602544	33418411	33556257	38075695	(4,519,438)
8	32275555	33385954	34602544	38075688	(3,473,144)
9	34017660	32275555	33385954	38075689	(4,689,735)
10	31810124	34017660	32275555	38075688	(5,800,133)
11	38686525	40951155	44715059	37772334	6,942,725
12	38046485	44052735	43562424	37772343	5,790,081
13	36975930	34617729	38046485	37772307	274,178
14	38969985	37772321	36975930	37772324	(796,394)
15	33385954	34602544	33418411	37772296	(4,353,885)
16	34617729	38046485	44052735	38046489	6,006,246
17	37130260	37936198	37036963	38046498	(1,009,535)
18	39266640	37282779	37033336	38046502	(1,013,166)
19	31631562	39266640	37282779	38046484	(763,705)
20	33173458	29746956	31631562	38046454	(6,414,892)
21	43993087	38838432	42526202	37322967	5,203,235
22	40163668	43687056	41762127	37322973	4,439,154
23	44052735	43562424	43262063	37322984	5,939,079
24	35872096	33690074	43777760	37322924	6,454,836
25	36031215	31810124	34017660	37322918	(3,305,258)
26	40951155	44715059	43993087	37322976	6,670,111
27	42333772	41917547	40163668	37322971	2,840,697
28	42090048	42333772	41917547	37322972	4,594,575
29	43262063	42090048	42333772	37322974	5,010,798
30	37322944	36798297	35872096	37322940	(1,450,844)
31	41762127	41084924	38686525	37772343	914,182

No	xt-2	xt-1	xt	prediction (xt)	selisih
32	43777760	40255558	40801483	37772347	3,029,136
33	37936198	37036963	37137337	37772319	(634,982)
34	37033336	37130260	37936198	37772316	163,882
35	33556257	33173458	29746956	37772293	(8,025,337)
36	44715059	43993087	38838432	37772371	1,066,061
37	37118014	38417540	36772328	37772321	(999,993)
38	37036963	37137337	38075717	37772316	303,401
39	37282779	37033336	37130260	37772316	(642,056)
40	29746956	31631562	39266640	37772267	1,494,373
41	41084924	38686525	40951155	37936215	3,014,940
42	43562424	43262063	42090048	37936238	4,153,810
43	36600388	38969985	37772321	37936203	(163,882)
44	38417540	36772328	36600388	37936201	(1,335,813)
45	36798297	35872096	33690074	37936193	(4,246,119)
46	41917547	40163668	43687056	37772342	5,914,714
47	40801483	37118014	38417540	37772328	645,212
48	33690074	43777760	40255558	37772328	2,483,230
49	37137337	38075717	37322944	37772320	(449,376)
50	33418411	33556257	33173458	37772293	(4,598,835)

Tabel 3 menjelaskan memang selisih yang dihasilkan tidak terlalu jauh dari data faktual. Terbukti dari beberapa data yang tidak jauh berbeda dengan data sebenarnya. Pada *record* data 13,34,38,49 membuktikan bahwa selisih yang sangat kecil sehingga menunjukkan bahwa *SVM-PSO* juga baik untuk prediksi. Untuk melihat keefektifan metode *SVM-PSO* dengan membandingkan dengan metode lainnya yakni *NN-GA*. Setelah dilakukan percobaan ternyata *RMSE* menunjukkan bahwa *NN-GA* memiliki *error* yang relatif kecil seperti terlihat pada Tabel 4.

Tabel 4. Prediksi menggunakan *NNGA*

No	xt-2	xt-1	xt	prediction	selisih
1	43,993,087	38,838,432	42,526,202	40,650,374	1,875,828
2	44,715,059	43,993,087	38,838,432	42,790,572	(3,952,140)
3	40,951,155	44,715,059	43,993,087	42,392,715	1,600,372
4	38,686,525	40,951,155	44,715,059	40,242,481	4,472,578
5	41,084,924	38,686,525	40,951,155	39,713,067	1,238,088
6	41,762,127	41,084,924	38,686,525	41,149,953	(2,463,428)
7	43,687,056	41,762,127	41,084,924	41,884,407	(799,483)
8	40,163,668	43,687,056	41,762,127	41,880,416	(118,289)
9	41,917,547	40,163,668	43,687,056	40,747,440	2,939,616
10	42,333,772	41,917,547	40,163,668	41,650,718	(1,487,050)
11	42,090,048	42,333,772	41,917,547	41,765,006	152,541
12	43,262,063	42,090,048	42,333,772	41,920,570	413,202
13	43,562,424	43,262,063	42,090,048	42,389,240	(299,192)
14	44,052,735	43,562,424	43,262,063	42,565,893	696,170
15	38,046,485	44,052,735	43,562,424	41,561,444	2,000,980

No	xt-2	xt-1	xt	prediction	selisih
16	34,617,729	38,046,485	44,052,735	37,234,163	6,818,572
17	36,975,930	34,617,729	38,046,485	36,025,108	2,021,377
18	37,772,321	36,975,930	34,617,729	37,619,973	(3,002,244)
19	38,969,985	37,772,321	36,975,930	38,495,111	(1,519,181)
20	36,600,388	38,969,985	37,772,321	38,439,806	(667,485)
21	36,772,328	36,600,388	38,969,985	37,073,616	1,896,369
22	38,417,540	36,772,328	36,600,388	37,708,678	(1,108,290)
23	37,118,014	38,417,540	36,772,328	38,275,913	(1,503,585)
24	40,801,483	37,118,014	38,417,540	38,701,303	(283,763)
25	40,255,558	40,801,483	37,118,014	40,611,695	(3,493,681)
26	43,777,760	40,255,558	40,801,483	41,274,733	(473,250)
27	33,690,074	43,777,760	40,255,558	40,296,972	(41,414)
28	35,872,096	33,690,074	43,777,760	35,260,273	8,517,487
29	36,798,297	35,872,096	33,690,074	36,661,358	(2,971,284)
30	37,322,944	36,798,297	35,872,096	37,367,540	(1,495,444)
31	38,075,717	37,322,944	36,798,297	37,928,679	(1,130,382)
32	37,137,337	38,075,717	37,322,944	38,075,241	(752,297)
33	37,036,963	37,137,337	38,075,717	37,476,872	598,845
34	37,936,198	37,036,963	37,137,337	37,710,295	(572,958)
35	37,130,260	37,936,198	37,036,963	37,988,447	(951,484)
36	37,033,336	37,130,260	37,936,198	37,471,463	464,735
37	37,282,779	37,033,336	37,130,260	37,494,692	(364,432)
38	39,266,640	37,282,779	37,033,336	38,296,613	(1,263,277)
39	31,631,562	39,266,640	37,282,779	36,995,105	287,674
40	29,746,956	31,631,562	39,266,640	33,350,258	5,916,382
41	33,173,458	29,746,956	31,631,562	33,361,471	(1,729,909)
42	33,556,257	33,173,458	29,746,956	34,494,044	(4,747,088)
43	33,418,411	33,556,257	33,173,458	34,615,413	(1,441,955)
44	34,602,544	33,418,411	33,556,257	34,828,005	(1,271,748)
45	33,385,954	34,602,544	33,418,411	35,053,494	(1,635,083)
46	32,275,555	33,385,954	34,602,544	34,307,096	295,448
47	34,017,660	32,275,555	33,385,954	34,253,607	(867,653)
48	31,810,124	34,017,660	32,275,555	34,448,016	(2,172,461)
49	36,031,215	31,810,124	34,017,660	34,494,704	(477,044)
50	35,164,149	36,031,215	31,810,124	36,253,368	(4,443,244)

Jika dilihat pada Tabel 4 pada dasarnya hasil uji coba tidak jauh berbeda antara *SVM-PSO* dan *NNGA*. *NNGA* juga menunjukkan pada *record* data 8, 11, 12, 13, 26, 27, 39, 46 yang memilih selisih yang relatif kecil. Jika ditotalkan memang relatif kecil selisih *SVM* terhadap *NNGA* hal itu terbukti pada Tabel 5.

Tabel 5. Perbandingan *RMSE*

	<i>RMSE</i>
<i>SVM-PSO</i>	3,541,155
<i>NNGA</i>	2,565,277
Selisih	975,878

Perbandingan *RMSE* tidak terlalu signifikan antara *SVM-PSO* dan *NN-GA* sehingga dapat disimpulkan juga hasil prediksi yang terbentuk dari optimasi *SVM-PSO* dapat melakukan prediksi konsumsi energi listrik di Gorontalo berdasarkan data yang diperoleh berdasarkan pada PLN Gorontalo.

Menghitung nilai *RMSE*

Untuk penghitungan nilai *RMSE* yang dipergunakan pada penelitian ini adalah seperti yang ditunjukkan pada Tabel 6.

Tabel 6. Penghitungan nilai *RMSE*

Bulan	<i>prediction</i> (p)	<i>Target</i> (t)	<i>Error</i> (p-t)	<i>Abs error</i> (e)	e ²
1	10	20	-10	10	100
2	30	10	20	20	400
3	30	40	-10	10	100
4	50	50	0	0	0
5	50	50	0	0	0
6	40	45	-5	5	25
7	45	55	-10	10	100
8	15	20	-5	5	25
9	25	55	-30	30	900
10	22	42	-20	20	400
11	12	21	-9	9	81
12	22	30	-8	8	64
TOTAL					2,195

Untuk menghitung nilai *RMSE*, diawali dengan menghitung nilai *MSE* terlebih dahulu.

$$\begin{aligned}
 MSE &= (\text{total absolute error})^2 / 3 \\
 &= (\text{total } |P - T|)^2 / 3 \\
 &= 2.195 / 12 \\
 &= 183
 \end{aligned}$$

$$\begin{aligned}
 RMSE &= \sqrt{MSE} \\
 &= \sqrt{183} \\
 &= 13.5
 \end{aligned}$$

KESIMPULAN

Berdasarkan hasil penelitian yang dilakukan menggunakan *SVM-PSO* pada dasarnya *SVM* merupakan algoritma klasifikasi. Tetapi pada kasus ini *SVM* digunakan untuk melakukan prediksi kombinasi antara *SVM-PSO* menghasilkan nilai *error* yang cukup baik meskipun tingkat akurasi masih kurang jika dibandingkan dengan algoritma prediksi lainnya (*NNGA*). Hal tersebut dikarenakan karena *NNGA* merupakan kombinasi algoritma yang memang telah terbukti keefektifannya pada penelitian-penelitian sebelumnya. Peneliti mencoba kombinasi baru dalam prediksi yakni *SVM-PSO* dan hasilnya cukup baik terbukti dari hasil analisis dan uji coba yang dilakukan dengan mendapatkan nilai selisih yang tidak jauh berbeda antara data faktual dan data hasil prediksi. Diharapkan kepada pengembangan/penelitian selanjutnya untuk melakukan pengujian terhadap *dataset* yang lebih banyak dan menambahkan algoritma optimasi lainnya.

REFERENSI

- Abas, M. I., & Lasarudin, A. (2019). Prediction of arrival domestic and foreign tourists based on regions using neural network algorithm based on genetic algorithm Prediction of arrival domestic and foreign tourists based on regions using neural network algorithm based on genetic algorithm. *IOP Conf. Series: Journal of Physics: Conf. Series* (2019) <https://doi.org/10.1088/1742-6596/1175/1/012045>
- Gorontalo, D. E. P. (2018). Wilayah Provinsi Gorontalo. *Artikel*, (2016).
- Juaidi, A., Montoya, F. G., Ibrik, I. H., & Manzano-agugliaro, F. (2016). An overview of renewable energy potential in Palestine. *Renewable and Sustainable Energy Reviews*, 65, 943–960. <https://doi.org/10.1016/j.rser.2016.07.052>
- Karazmodeh, M., Nasiri, S., & Hashemi, S. M. (2013). Stock Price Forecasting using Support Vector Machines and Improved Particle Swarm Optimization. *Journal of Automation and Control Engineering*, 1(2), 173–176. <https://doi.org/10.12720/joace.1.2.173-176>
- Purwanto., Eswaran, C., & Logeswaran, R. (2011). Improved Adaptive Neuro-Fuzzy Inference System for HIV/AIDS Time Series Prediction. *Informatics Engineering and Information Science, Pt Iii*, 253, 1–13. https://doi.org/10.1007/978-3-642-25462-8_1.
- Zhang, L., Ge, R., & Chai, J. (2019). Prediction of China's energy consumption based on robust principal component analysis and PSO- LSSVM optimized by the Tabu Search Algorithm, 1–21. <https://doi.org/10.3390/en12010196>